

Wykład 4: Podstawowe własności estymatorów

W wykładzie tym przedstawimy kryteria pozwalające ocenić jakość danego estymatora, bądź wybrać z pewnego zbioru ten, który w pewnym sensie jest najlepszy.

Estymatory nieobciążone

Zacznijmy od wprowadzenia definicji.

Definicja. Mówimy, że $\hat{\theta} = t(X_1, X_2, \dots, X_n)$ jest *nieobciążonym estymatorem* parametru θ jeśli

$$E_{\theta}(\hat{\theta}) = \theta \quad \text{dla każdego } \theta \in \Theta.$$

W pozostałych przypadkach $\hat{\theta}$ nazywamy *estymatorem obciążonym*. Funkcję $B(\theta) = E_{\theta}(\hat{\theta}) - \theta$, gdzie $\theta \in \Theta$, nazywamy *obciążeniem estymatora* $\hat{\theta}$.

Z powyższych definicji natychmiast wynika, że $\hat{\theta}$ jest estymatorem nieobciążonym wtedy i tylko wtedy, gdy jego obciążenie jest funkcją tożsamościowo równą zero.

Przykład 4.1. Niech X_1, X_2, \dots, X_n będzie prostą próbą losową z populacji X o rozkładzie z wartością oczekiwaną $EX = \mu$. Wówczas $\hat{\mu} = \bar{X}$ jest nieobciążonym estymatorem parametru μ . Rzeczywiście dla dowolnego μ otrzymujemy

$$E_{\mu}(\hat{\mu}) = E_{\mu}(\bar{X}) = E_{\mu}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E_{\mu}(X_i) = \frac{1}{n} \sum_{i=1}^n \mu = \frac{1}{n} n\mu = \mu.$$

Dla X o rozkładzie dwupunktowym z prawdopodobieństwem sukcesu p mamy $EX = p$. Zatem jako szczególny przypadek powyższego wyniku otrzymujemy, że jeśli X_1, X_2, \dots, X_n jest prostą próbą losową z populacji X o rozkładzie dwupunktowym z prawdopodobieństwem sukcesu p , to $\hat{p} = \bar{X}$ jest nieobciążonym estymatorem parametru p .

Przykład 4.2. Niech X_1, X_2, \dots, X_n będzie prostą próbą losową z populacji X o rozkładzie z wartością oczekiwaną $EX = \mu$ i wariancją $Var(X) = \sigma^2 > 0$. Załóżmy, że nie znamy ani μ ani σ^2 . Wówczas

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

jest estymatorem obciążonym parametru σ^2 , bo

$$E_{(\mu, \sigma^2)}(\hat{\sigma}^2) = \frac{n-1}{n} \sigma^2 \neq \sigma^2,$$

natomiast

$$\hat{\sigma}_{no}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

jest estymatorem nieobciążonym σ^2 .

Aby to pokazać zauważmy najpierw, że

$$\begin{aligned} \sum_{i=1}^n (X_i - \bar{X})^2 &= \sum_{i=1}^n (X_i - \mu - (\bar{X} - \mu))^2 = \sum_{i=1}^n (X_i - \mu)^2 - 2(\bar{X} - \mu) \sum_{i=1}^n (X_i - \mu) + n(\bar{X} - \mu)^2 = \\ &= \sum_{i=1}^n (X_i - \mu)^2 - 2n(\bar{X} - \mu)^2 + n(\bar{X} - \mu)^2 = \sum_{i=1}^n (X_i - \mu)^2 - n(\bar{X} - \mu)^2, \end{aligned}$$

bo $\sum_{i=1}^n (X_i - \mu) = n \cdot \frac{1}{n} \sum_{i=1}^n X_i - n\mu = n(\bar{X} - \mu)$. Stąd

$$\begin{aligned} E_{(\mu, \sigma^2)}(\hat{\sigma}^2) &= E_{(\mu, \sigma^2)} \left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \right) = \frac{1}{n} E_{(\mu, \sigma^2)} \left(\sum_{i=1}^n (X_i - \mu)^2 - n(\bar{X} - \mu)^2 \right) \\ &= \frac{1}{n} \left[E_{(\mu, \sigma^2)} \left(\sum_{i=1}^n (X_i - \mu)^2 \right) - n E_{(\mu, \sigma^2)}(\bar{X} - \mu)^2 \right] = \frac{1}{n} (n\sigma^2 - \sigma^2) = \sigma^2 \frac{n-1}{n}, \end{aligned}$$

ponieważ

$$E_{(\mu, \sigma^2)}(X_i - \mu)^2 = E_{(\mu, \sigma^2)}(X_i - E_{(\mu, \sigma^2)}(X_i))^2 = \text{Var}_{(\mu, \sigma^2)}(X_i) = \sigma^2$$

oraz, zgodnie z tym, co pokazaliśmy w przykładzie 4.1, $E_{\mu}(\bar{X}) = \mu$, co pociąga za sobą

$$\begin{aligned} E_{(\mu, \sigma^2)}(\bar{X} - \mu)^2 &= E_{(\mu, \sigma^2)}(\bar{X} - E_{(\mu, \sigma^2)}(\bar{X}))^2 = \text{Var}_{(\mu, \sigma^2)}(\bar{X}) = \text{Var}_{(\mu, \sigma^2)} \left(\frac{1}{n} \sum_{i=1}^n X_i \right) = \\ &= \frac{1}{n^2} \sum_{i=1}^n \text{Var}_{(\mu, \sigma^2)}(X_i) = \frac{1}{n^2} \cdot n\sigma^2 = \frac{1}{n} \sigma^2. \end{aligned}$$

Wprowadzając drobną modyfikację w mianowniku estymatora $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$, przerebimy go na estymator nieobciążony. Rzeczywiście

$$\begin{aligned} E_{(\mu, \sigma^2)} \left(\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \right) &= E_{(\mu, \sigma^2)} \left(\frac{n}{n-1} \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \right) = \frac{n}{n-1} E_{(\mu, \sigma^2)}(\hat{\sigma}^2) \\ &= \frac{n}{n-1} \frac{n-1}{n} \sigma^2 = \sigma^2, \end{aligned}$$

co pokazuje, że $\hat{\sigma}_{no}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ jest estymatorem nieobciążonym σ^2 .

Choć, w przypadku próby losowej z rozkładu o istniejących ale nieznanymi wartości oczekiwanej μ i wariancji σ^2 , estymator $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ jest obciążonym estymatorem σ^2 , to wraz ze wzrostem liczności próby jego obciążenie maleje do zera:

$$\lim_{n \rightarrow \infty} E_{(\mu, \sigma^2)}(\hat{\sigma}^2) = \lim_{n \rightarrow \infty} \frac{n-1}{n} \sigma^2 = \sigma^2,$$

a stąd

$$\lim_{n \rightarrow \infty} B(\hat{\sigma}^2) = \lim_{n \rightarrow \infty} (\sigma^2 - E_{(\mu, \sigma^2)}(\hat{\sigma}^2)) = 0.$$

Estymator o takiej własności (a precyzyjniej - ciąg estymatorów $\hat{\theta}_n$, gdzie n to liczność próby losowej) nazywamy asymptotycznie nieobciążonym.

Definicja. Mówimy, że ciąg estymatorów $\hat{\theta}_n = t_n(X_1, X_2, \dots, X_n)$ parametru θ jest *asymptotycznie nieobciążony* jeśli

$$\lim_{n \rightarrow \infty} E_{\theta}(\hat{\theta}_n) = \theta \quad \text{dla każdego } \theta \in \Theta.$$

Estymatory nieobciążone o minimalnej wariancji

Nieobciążoność danego estymatora nie gwarantuje nam, że jest on dobry - przyjmowane przez niego wartości mogą być bardzo rozproszone wokół θ . Bardziej porządną własnością od nieobciążoności jest by rozproszenie estymatora wokół szacowanej θ było możliwie najmniejsze. Rozproszenie to możemy mierzyć jako wartość oczekiwana z kwadratu różnicy między estymatorem i θ .

Definicja. Funkcję

$$MSE_{\hat{\theta}}(\theta) = E_{\theta} \left(\hat{\theta} - \theta \right)^2, \quad \text{gdzie } \theta \in \Theta,$$

nazywamy *błędem średniokwadratowym estymatora* $\hat{\theta}$ parametru θ .

Najlepszym estymatorem byłby estymator minimalizujący błąd średniokwadratowy dla wszystkich $\theta \in \Theta$. Niestety, poza wyjątkowo rzadkimi przypadkami, taki estymator nie istnieje. Jeśli jednak ograniczymy zbiór rozważanych estymatorów do nieobciążonych, to sytuacja ulegnie zmianie.

Zauważmy, że

$$\begin{aligned} MSE_{\hat{\theta}}(\theta) &= E_{\theta} \left(\hat{\theta} - \theta \right)^2 = E_{\theta} \left(\hat{\theta} - E_{\theta}\hat{\theta} - (\theta - E_{\theta}\hat{\theta}) \right)^2 \\ &= E_{\theta} \left(\hat{\theta} - E_{\theta}\hat{\theta} \right)^2 - 2(\theta - E_{\theta}\hat{\theta})E_{\theta} \left(\hat{\theta} - E_{\theta}\hat{\theta} \right) + (\theta - E_{\theta}\hat{\theta})^2 = \\ &= Var_{\theta}(\hat{\theta}) + (B(\theta))^2, \end{aligned} \quad (1)$$

bo $E_{\theta} \left(\hat{\theta} - E_{\theta}\hat{\theta} \right) = E_{\theta}\hat{\theta} - E_{\theta} \left(E_{\theta}\hat{\theta} \right) = E_{\theta}\hat{\theta} - E_{\theta}\hat{\theta} = 0$. Oznacza to, że błąd średniokwadratowy estymatora to suma jego wariancji i kwadratu obciążenia. Błąd ten zatem będzie mały jedynie, gdy zarówno wariancja estymatora jak i jego obciążenie będą małe. Natomiast dla nieobciążonych estymatorów $\hat{\theta}$ parametru θ wzór (1) redukuje się do

$$MSE_{\hat{\theta}}(\theta) = Var_{\theta}(\hat{\theta}),$$

i minimalizowanie błędu średniokwadratowego jest równoważne minimalizowaniu wariancji.

Definicja. Estymator $T_0 = t(X_1, \dots, X_n)$ nazywamy *estymatorem nieobciążonym o minimalnej wariancji* parametru θ , jeśli

1. T_0 jest nieobciążony, tzn. dla każdego $\theta \in \Theta$ mamy $E_{\theta}(T_0) = \theta$,
2. $Var_{\theta}(T_0) \leq Var_{\theta}(T)$ dla każdego $\theta \in \Theta$ i dla każdego estymatora nieobciążonego T parametru θ .

W literaturze anglosaskiej estymator nieobciążony o minimalnej wariancji w skrócie nazywa się UMVUE od *uniformly minimum-variance unbiased estimator*.

Estymatory zgodne

Niech X_1, X_2, \dots będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie zależnym od parametru $\theta \in \Theta$. Dla dowolnego naturalnego n tworzymy próbę losową X_1, X_2, \dots, X_n i na jej podstawie budujemy estymator $\hat{\theta}_n = t_n(X_1, X_2, \dots, X_n)$ parametru θ .

Definicja. Mówimy, że ciąg estymatorów $\hat{\theta}_n = t_n(X_1, X_2, \dots, X_n)$, $n \geq 1$, parametru θ jest

- *zgodny w sensie zbieżności średniokwadratowej* jeśli błąd średniokwadratowy $\hat{\theta}_n$ zbiega do zera wraz ze wzrostem liczności próby do nieskończoności:

$$\lim_{n \rightarrow \infty} E \left((\hat{\theta}_n - \theta)^2 \right) = 0 \quad \text{dla wszystkich } \theta \in \Theta;$$

- *mocno zgodny* jeśli z prawdopodobieństwem 1 realizacje $\hat{\theta}_n$ dążą do θ , gdy liczność próby wzrasta do nieskończoności

$$P \left(\lim_{n \rightarrow \infty} \hat{\theta}_n = \theta \right) = 1 \quad \text{dla wszystkich } \theta \in \Theta;$$

- (*slabo*) zgodny jeśli dla dostatecznie dużych licznosci próby estymator $\hat{\theta}_n$ z dużym prawdopodobieństwem przyjmuje wartości bliskie θ :

$$\lim_{n \rightarrow \infty} P(|\hat{\theta}_n - \theta| < \varepsilon) = 1 \quad \text{dla każdego } \varepsilon > 0 \text{ i dla wszystkich } \theta \in \Theta.$$

W terminach rodzajów zbieżności ciągów zmiennych losowych

- zgodność w sensie zbieżności średniokwadratowej oznacza, że ciąg $\hat{\theta}_n$ zbiega w sensie zbieżności średniokwadratowej do θ : $\hat{\theta}_n \xrightarrow{L^2} \theta$;
- mocna zgodność oznacza, że ciąg $\hat{\theta}_n$ zbiega z prawdopodobieństwem 1 (prawie na pewno) do θ : $\hat{\theta}_n \xrightarrow{1} \theta$;
- słaba zgodność oznacza, że ciąg $\hat{\theta}_n$ zbiega według prawdopodobieństwa do θ : $\hat{\theta}_n \xrightarrow{P} \theta$.

Z teorii rachunku prawdopodobieństwa wynika, że każdy estymator zgodny w sensie zbieżności średniokwadratowej jak i każdy estymator mocno zgodny jest zgodny.

Podane niżej twierdzenie przyda nam się do uzasadnienia, że średnia próbkowa jest mocno zgodnym estymatorem średniej populacyjnej.

Twierdzenie 4.1 (Mocne prawo wielkich liczb Kołmogorowa). Jeśli X_1, X_2, \dots jest ciągiem niezależnych zmiennych losowych o tym samym rozkładzie ze skończoną wartością oczekiwaną μ , to

$$\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{1} \mu \quad \text{tzn.} \quad P\left(\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n X_i = \mu\right) = 1.$$

Przykład 4.3. Niech X_1, X_2, \dots będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie z nieznaną wartością oczekiwaną μ . Z mocnego prawa wielkich liczb Kołmogorowa natychmiast wynika, że $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ jest mocno zgodnym estymatorem parametru μ . Stąd \bar{X}_n jest też słabo zgodnym estymatorem μ .

Jeśli dodatkowo założymy, że X_1, X_2, \dots mają wariancję σ^2 , to otrzymamy, że \bar{X}_n jest także zgodnym w sensie zbieżności średniokwadratowej estymatorem μ . Rzeczywiście, skoro μ jest nieobciążonym estymatorem μ , to otrzymujemy

$$E((\bar{X}_n - \mu)^2) = E((\bar{X}_n - E(\bar{X}_n))^2) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{1}{n^2} n \sigma^2 = \frac{\sigma^2}{n} \xrightarrow{n \rightarrow \infty} 0.$$

Następny przykład podamy bez dowodu.

Przykład 4.4. Niech X_1, X_2, \dots będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie z nieznanymi wartością oczekiwaną μ i wariancją σ^2 . Wtedy

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \quad \text{i} \quad \hat{\sigma}_{no}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

są mocno zgodnymi estymatorami parametru σ^2 . Zatem są to także estymatory słabo zgodne. Ponadto, przy dodatkowym założeniu, że X_1, X_2, \dots mają skończony czwarty moment centralny, zarówno $\hat{\sigma}^2$ jak i $\hat{\sigma}_{no}^2$ są zgodnymi w sensie zbieżności średniokwadratowej estymatorami parametru σ^2 .